

# Deep Learning を利用したコンクリート骨材の AI 判別技術に関する研究

佐藤英明\*

コンクリートの品質管理において、骨材の誤投入、誤混入は排除すべき重要な課題である。本研究では、骨材の新しい誤投入防止技術として、Deep Learning による骨材の粒径および岩種の AI 判別技術について研究を行った。また、骨材の粒度分布推定に関する AI 技術の応用についても研究を行った。その結果、良質で十分なデータ量に基づく AI による画像認識技術を用いることで、骨材全量の粒径および岩種を瞬時に判別できるだけでなく、粒度分布についても十分な精度で推定できることが明らかとなった。

キーワード：骨材，誤投入防止，AI，Deep Learning，粒度分布

## 1. はじめに

コンクリート製造設備では、骨材は通常それぞれの粒径の範囲に応じた所定の貯蔵ビンへ投入、貯蔵されるが、粒径別の骨材貯蔵ビンへの誤投入が生じないよう慎重な運転管理が求められている。一方、骨材貯蔵ビンへ粒径の異なる骨材が投入された場合、コンクリートの品質を確保するために骨材貯蔵ビン内の骨材を全量撤去し入れ替えなければならず、費用的にも工程的にも大きな支障を及ぼすこととなる。そこで、納品書（納品伝票）や RFID（Radio Frequency Identifier：一般に IC タグ）を利用した管理方式などによって誤投入の防止が図られているが、これらの方法でもデータの誤入力や設備の誤操作など、人的ミスの発生を完全には排除するのが難しかった。

このような背景を踏まえ、筆者はステレオカメラを利用した三次元画像処理技術による骨材判別システムを開発し、切目川ダムの施工現場にて全骨材の粒径判別の試験運用を行ってきた（平成 29 年度ダム工学会技術開発賞を受賞）<sup>1),2)</sup>。さらに、その撮影画像を基に、最新の AI（Artificial Intelligence: 人工知能）技術による骨材判別を試み、既往の画像処理に比べて判定率が向上できることを確認してきた<sup>3),4)</sup>。

本報告では、AI による骨材粒径判別技術について、これまでの研究経緯ならびにステレオカメラと画像処理による方法に対する判別精度の違いや AI における判別精度の向上の試みについて示すと共に、岩種の判別や実プラントでの粒度分布推定方法に関する研究結果<sup>5)</sup>を踏まえて、骨材の全量判別への可能性について示すものである。

## 2. Deep Learning による骨材粒径判別の研究

### 2. 1 AI における Deep Learning について

近年、AI 研究の急速な発展に伴い、様々な分野で AI の

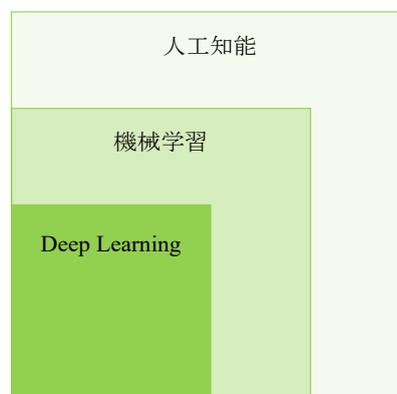


Fig. 1 人工知能，機械学習および Deep Learning の関係

導入が進められている。とりわけ、2006 年頃から始まったと言われている第三次 AI ブームにおいて Deep Learning（深層学習）による画像認識技術が開発されてからは AI の飛躍的な進化が進んでいる。

Deep Learning は、十分なデータ量があれば工学的なロジックによることなく、データから自動的に特徴の抽出を行うニューラルネットワークというアルゴリズムを多層化したディープニューラルネットワークを用いた学習のことであり、機械学習の一つとして位置付けられている。一方、機械学習も人工知能の要素技術の一つであり、それぞれの関係を模式的に示すと Fig. 1 のとおりとなる。

Deep Learning が得意とする分野は画像認識といえるが、現在では音声認識や言語処理、映像解析など様々な技術への応用・実用化が研究されている。

なお、Deep Learning にも教師あり学習や教師なし学習などがあるが、本研究では、教師データにより学習モデルを作成して推論する方法で行うものとした。

### 2. 2 ダムコンクリート用骨材による検証

#### 2. 2. 1 Deep Learning における教師データ

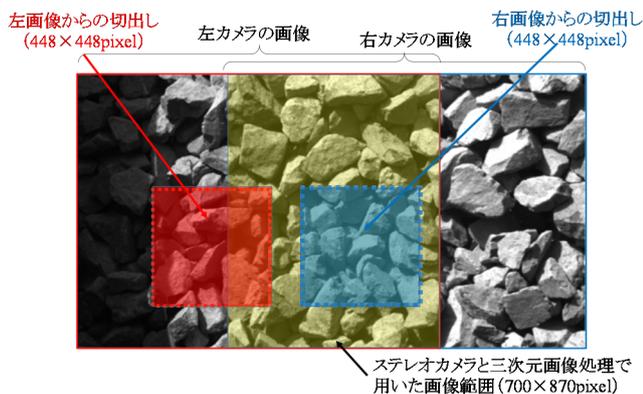
Deep Learning によって骨材の粒径の判別の可能性を検証するために、既往の切目川ダムにおいてダンプトラックの全荷台を撮影した粗骨材 3 種類（G1：80～40mm，G2：40

\* 土木事業本部 ダム技術部

**Table 1 ダムコンクリート用骨材の諸元および粗粒率**

区分	粗骨材			細骨材
	G1 80~40mm	G2 40~20mm	G3 20~5mm	S
骨材種類	碎石			山砂
産地/岩種	兵庫県赤穂市産/流紋岩質溶結凝灰岩			
粗粒率 <sup>※)</sup>	8.98~9.09	7.90~7.99	6.58~6.83	2.62~2.95

※) 約一年間の変動範囲



**Fig. 2 ステレオカメラによる撮影画像からの Deep Learning の判定画像の切出し**

~20mm, G3: 20~5mm) および細骨材 1 種類 (S: 5mm 以下), 計 4 種類の画像<sup>2)</sup>を用いることとした. Table 1 に, 使用したダムコンクリート用骨材の諸元および粗粒率を示す.

今回の Deep Learning では, ステレオカメラと画像処理による判定時に撮影した全骨材の左右合計 26,079 枚 (荷台画像等を除く) のモノクロ画像から, 寸法 22.4x22.4cm (448x448pixel, 分解能: 約 0.5mm/pixel) に機械的に切り出して AI 用画像とした (Fig. 2).

### 2. 2. 2 AI 学習モデルと AI 粒径判別の概要

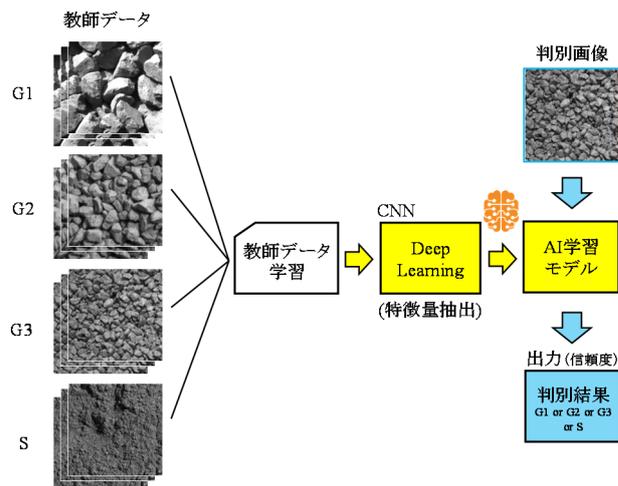
AI モデルは, 切り出した全画像からランダムに骨材種類毎に各 250 枚, 計 1,000 枚を抽出した画像を Deep Learning によって学習し構築した. この AI 学習モデルを用いて, 残りの切出し画像 25,079 枚 (=26,079-1,000) について骨材粒径の AI 判別を行った.

なお, Deep Learning にも幾つかのアルゴリズムがあるが, 本研究では画像に対して高いパターン認識能力があると言われている畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いた. CNN は市販のソフトを使用し, 各パラメータはメーカーの推奨値を参考にエポック数 (全学習の繰り返し回数) は 300 とし, 学習率 (学習の強制力を調整する値) は 0.001 ならびにモメンタム (収束度合いを調整する値) は 0.8 とした.

Fig. 3 に, 教師データによる Deep Learning の学習 (画像識別) モデルの構築とそれを用いた AI 骨材粒径判別の模式図を示す.

### 2. 2. 3 Deep Learning による骨材粒径判別結果

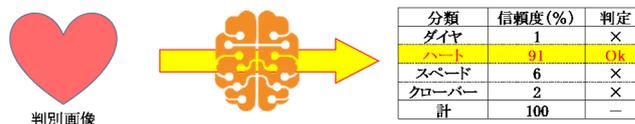
Table 2 に, Deep Learning による骨材粒径判別結果を



**Fig. 3 教師データによる AI 学習モデルと AI 骨材粒径判別の模式図**

**Table 2 Deep Learning によるダムコンクリート用骨材の粒径判別結果**

区分	Deep Learning				ステレオカメラと三次元画像処理				
	総数	Ok	誤判定	判定率	総数	Ok	誤判定	判定率	
粗骨材	G1 (80~40mm)	5,471	5,450	21	99.6	2,706	2,663	43	98.4
	G2 (40~20mm)	5,842	5,834	8	99.9	2,794	2,707	87	96.9
	G3 (20~5mm)	6,724	6,696	28	99.6	3,241	3,196	45	98.6
細骨材	S (≤5mm)	7,042	7,042	0	100.0	3,384	3,384	0	100.0
合計	25,079	25,022	57	99.8	12,125	11,950	175	98.6	



**Fig. 4 信頼度についてのイメージ**

従来のステレオカメラと三次元画像処理による結果<sup>2)</sup>と併せて示す.

この結果, Deep Learning による正しく判別 (Ok: 信頼度 90% 以上のものとした.) できた画像は 25,022 枚, 誤判定は僅か 57 枚で, 判定率 (=Ok/総数) は 99.8% であり, これまでのステレオカメラと三次元画像処理による判定率 (98.6%) に比べて 1.2 ポイント向上した結果となった. 特に, 粗骨材については, 誤判定が大幅に低減できた. 細骨材については, 何れの方法によっても判定率は 100% であった.

これより, 良質な教師データを用いて Deep Learning による信頼性の高い学習モデルを構築することで, 骨材粒径の高い判別が可能であることが確認できた.

なお, Deep Learning における信頼度とは, 予測が正しいことの確からしさの程度を示し, 判別画像に対する各分類 (ここでは 4 分類) に対して合計が 100% となるように識別の程度が割り当てられる値を言う. 例えば, 判別画像

Table 3 ダムコンクリート用骨材のAI 誤判定画像の一例

区分	粗骨材G1	粗骨材G2	粗骨材G3
画像			
AI判定	G2	G3	S
誤判定原因	画像中央部に細粒分が多い	斜光で荷台の影が写っている	表面が濡れて反射している

(ハート)において、判別4分類に対するAIの信頼度が、Fig.4に示すようにダイヤ、スペードおよびクローバーは小さく、ハートが91%と最大となったとすると、この画像に対するAIによる判定はハートとして認識されることとなる。

一方、Table 2に示したDeep Learningにおける誤判定画像57件について、その一例をTable 3に示す。このように誤判定画像については、骨材が偏っている画像や太陽光の斜光、降雨などの影響を受けた撮影状況の悪い画像が多く、それが判定率低下の原因となって誤判定となったものと思われる。

すなわち、画像のDeep Learningでは、学習階層の調整やデータ量も重要であるが、撮影照度や撮影距離・解像度・輝度・撮影角度など安定した撮影環境により画像の質を向上させることも判定率に重要な影響を及ぼすものと考えられる。

### 2. 2. 4 AI判定率の向上に関する検討

今回のDeep Learningでは、計算機の処理能力負荷の関係などを考慮して画像のサイズを448×448pixelとしたが、特に骨材粒径が大きい場合には粒径が偏った狭い範囲を撮影してしまうこともあり誤判定となるケースも見受けられた(Table 3およびPhoto.1)。そこで、切出し範囲をより拡大することで、粒径の大きい粗骨材についての誤判定が低減できると考え、AI判定率向上の可能性について検討を行った。

以下では、画像の切出し範囲を448×448pixelから新たに1.5倍に拡大した672×672pixelとした。ただし、Deep Learningによる判別画像は、これまでと同様のサイズとし、拡大した範囲を5分割して各画像について判定を行う方法をとった。なお、総合的な判別は、画像判別結果が3/5以上同じであれば、それを当該画像の骨材粒径の判別結果とするものとした(Fig.5)。

Table 4に、切出し範囲を1.5倍に拡大し5分割画像としてDeep Learningした場合の判定結果を示す。なお、Table 2で示した一ヶ所の切出し画像による判別結果は、Fig.5における位置3(左下)と同一である。

この結果、判別する骨材の画像切出し範囲を1.5倍に拡大し、5分割して3/5が一致したものをOkとすることで、誤判定画像は一ヶ所の場合に比べて57枚から43枚に低減



Photo. 1 粒径の小さい骨材が多く写る誤判定画像の一例

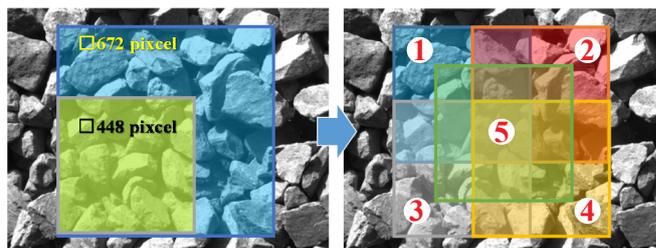


Fig. 5 画像の切出し範囲の拡大と判別画像の分割

Table 4 複数画像の総合判定に基づくAI粒径判別結果

位置		Deep Learning							判定率
		総数	Ok	誤判定				計	
				G1	G2	G3	S		
1	左上	25,079	25,012	26	12	25	4	67	99.8 (99.773)
2	右上	25,079	25,015	16	14	32	2	64	99.7 (99.743)
3	左下	25,079	25,022	21	8	28	0	57	99.8 (99.773)
4	右下	25,079	25,018	15	9	35	2	61	99.8 (99.757)
5	中央	25,079	25,020	20	7	31	1	59	99.8 (99.765)
総合判定		25,079	25,036	12	4	27	0	43	99.8 (99.829)

注)総合判定では、3ヶ所以上一致したものをOkとした。

でき、低減の傾向は骨材の粒径が大きいほど誤判定が低減(G1:21→12枚, G2:8→4枚, G3:28→27枚に低減)する傾向がみられた。これより、判定率は一ヶ所の判定(99.773%)に比べて99.829%とごく僅かではあるが向上できることが明らかとなった。

これより、ダムコンクリート用骨材のように粒径の大きい粗骨材のDeep Learningにおいては、判別する画像エリアは大きいほど判定精度の向上が期待できるものと考えられる。

### 2. 3 一般コンクリート用骨材による検証

#### 2. 3. 1 検証骨材の諸元と判別画像の撮影

前述のダムコンクリート用骨材のDeep Learningで構築

**Table 5 一般コンクリート用骨材の諸元**

区分	粗骨材(20~5mm)		細骨材		
	I	II	A	B	C
産地	高知県吾川産	茨城県桜川産	千葉県富津産	静岡県掛川産	茨城県桜川産
岩種	石灰石砕石	硬質砂岩砕石	山砂	山砂	硬質砂岩砕砂
表乾密度 (g/cm <sup>3</sup> )	2.70	2.66	2.61	2.58	2.64
絶乾密度 (g/cm <sup>3</sup> )	2.69	2.65	2.55	2.53	2.62
吸水率 (%)	0.67	0.49	2.37	2.02	0.84
粗粒率	6.61	6.68	2.58	2.68	2.77



**Photo. 2 一般コンクリート骨材の判別画像の撮影状況**

した学習モデルを用いて、産地や岩種の異なる数種類の一般コンクリート用骨材についても粒径判別が可能か検証を行った。

Table 5 に、判別に用いた一般コンクリート用骨材を示す。骨材は、産地、岩種および物性値などが異なる粗骨材 2 種類（何れも 20~5mm）、細骨材 3 種類の計 5 種類とした。なお、これらの骨材は、何れも学習モデルの教師データとしたダムコンクリート用骨材とは品質などが異なるものである。

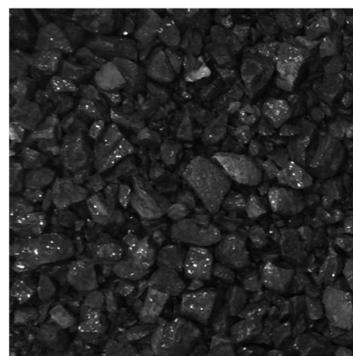
各骨材の判別画像は、それぞれ大型バットに敷き均して、寸法を補正するためのゲージを骨材表面に設置して iPad によりカラー撮影を行った (Photo. 2)。また、各骨材の表面状態については、実際の現場状況をイメージして、ほぼ表乾状態の屋内（室内光/日陰）および屋外（太陽光/日向）、また屋内（室内光）にて骨材表面に散水した 3 パターンとし、撮影位置や表面の状態などを変えながら各 100 枚ずつ計 1,500 枚の撮影を行った。判別画像は、学習モデルの教師データに合わせて、分解能を約 0.5mm/pixel、画像寸法を約 22.4×22.4cm(448×448pixel)に切り出し、モノクロ画像に変換して使用した。

### 2. 3. 2 ダムコンクリート用骨材による学習モデルを用いた Deep Learning による骨材粒径判別結果

Table 6 に、ダムコンクリート用骨材を使って学習した AI 学習モデルを用いた一般コンクリート用骨材の Deep Learning による骨材粒径判別結果を示す。この結果、誤判定は僅か 1 枚で判定率は 99.9%であった。

**Table 6 一般コンクリート用骨材の AI 判別結果**

区分	Deep Learning				
	総数	Ok	誤判定	判定率	
粗骨材 (20~5mm)	I	600	599	1	99.8
	II				
細骨材	A	900	900	0	100.0
	B				
	C				
合計	1,500	1,499	1	99.9	



**Photo. 3 誤判定となった粗骨材 (20~5mm) 画像**

これより、教師データとは異なる骨材でも、粒径の範囲が同じ規格であれば、Deep Learning によって十分に精度良く骨材の粒径判別が可能であることが明らかとなった。

なお、誤判定となった粗骨材画像 (Photo. 3 参照) は、骨材に散水した画像であり表面に反射が見られ、その影響によるものか定かではないが、同じ骨材における他の画像に比べてやや大きく見えるイメージであった。

## 3. Deep Learning による骨材岩種判別の研究

### 3. 1 カラー画像を用いた一般コンクリート用骨材による岩種判別の検証

前章までの Deep Learning による画像認識では、モノクロ写真を利用しているため、含有鉱物など岩種による骨材表面の色合いが異なる場合でも粒径の判別ができるメリットがあった。一方、コンクリートの骨材は必ずしも一つの産地のものだけでなく、同一粒径でも 2 種類以上の異なった粗粒率のものを混合して用いられる場合も多く、コンクリート製造設備ではこれらが誤混入することなく分別・貯蔵して品質管理を行わなければならない。

そこで本章では、これまで骨材粒径判別で示した Deep Learning を用いて、コンクリート骨材の岩種判別の可能性について検討を行った。

### 3. 2 骨材カラー画像による教師データと AI 岩種判別モデル

岩種の判定の Deep Learning に用いた骨材の画像は、前章で撮影した産地および岩種の異なる粗骨材 (20~5mm) 2

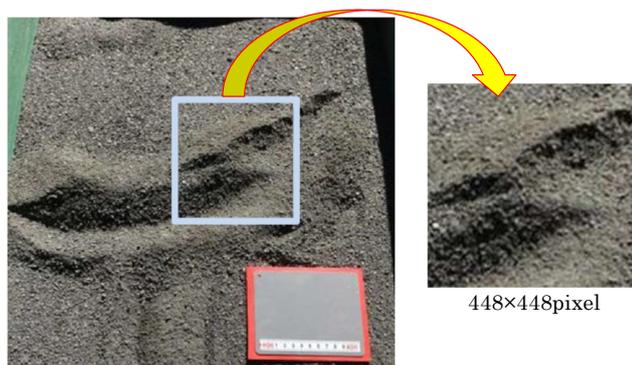


Fig. 6 ホワイトバランス補正用治具（寸法調整スケールを含む）と Deep Learning 用画像の切出し

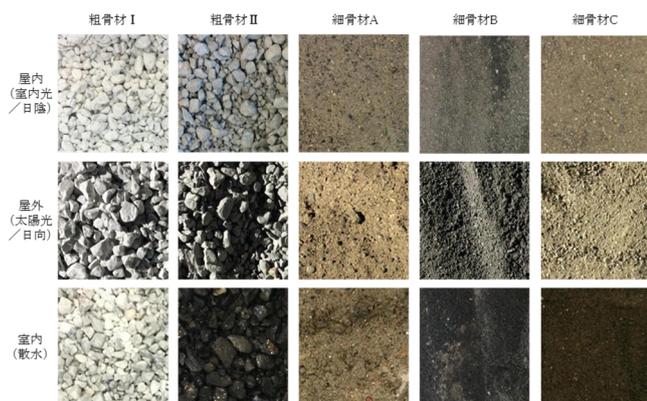


Fig. 7 各骨材のカラー撮影による教師データ画像の一例

種類、細骨材 3 種類の計 5 種類とした (Table 5 参照)。

通常カラー画像では、撮影時のホワイトバランスによって色合いが異なってしまうため、正確な画像の色調補正が重要である。そこで、骨材撮影時にホワイトバランスを補正するための専用治具を骨材画像に映り込むように設置して、撮影を行った。なお、骨材の表面状態は、前述と同様、表乾状態（屋内、屋外）と、散水状態（屋内）とし、それぞれの画像を撮影した。撮影画像は、専用治具のグレイパネル（RGB における 256 階調の中央値）とスケールで色調および距離補正を行い、分解能を約 0.3mm/pixel、約 13.44 × 13.44cm（448 × 448pixel）に切り出して Deep Learning に用いた (Fig. 6)。

教師データは、合計 1,500 枚 (=表面状態 3 パターン × 骨材 5 種類 × 各 100 枚) の画像から、骨材毎にランダムに 60 枚 (屋内 / 日陰・屋外 / 日向および屋内散水: 各 20 枚) 計 300 枚を抽出して用いた。Fig. 7 に、各骨材の学習に用いた教師データ画像の一例を示す。なお、Deep Learning による学習モデルの構築方法については、骨材粒径判別と同様に CNN を用いて行った (Fig. 3 参照)。

### 3. 3 Deep Learning による骨材岩種判別結果

Deep Learning による骨材種別の判別に用いた検証用画像は、学習用画像を除いた各骨材 80 枚ずつ計 1,200 枚とした。Table 7 に、各骨材についての判別結果を示す。

この結果、検証画像 1,200 枚中、誤判定は 5 枚で、判定

Table 7 各骨材の岩種判別結果

区分		Deep Learning			
		総数	Ok	誤判定	判定率
粗骨材 (20~5mm)	I	240	240	0	100.0
	II	240	240	0	100.0
細骨材	A	240	236	4	98.3
	B	240	240	0	100.0
	C	240	239	1	99.6
合計		1,200	1,195	5	99.6

Table 8 骨材岩種の誤判定画像の一例

検証画像		
骨材種別	細骨材 A	細骨材 C
撮影状態	屋内 (散水)	屋外
判別結果	細骨材 C	細骨材 A
信頼度 (%)	86.6	62.5

率は 99.6% であった。骨材別では、粗骨材については I、II 共に判定率が 100% であったが、細骨材については細骨材 B が 100% であるものの、細骨材 A および C については何れも A を C に、C を A とした計 5 枚の誤判定があった。これらの誤判定画像は、何れも目視でも分別が難しいような色調が類似した細骨材であり、AI による信頼度は全て 90% 未満 (51.7~87.3%) であった (Table 8)。

すなわち、的確かつ信頼性のあるカラー画像による教師データを用いて学習モデルを構築することで、同じ粒径（寸法）範囲の骨材であっても異なる岩種の骨材を実用上問題ない精度で判別可能であることが明らかとなった。なお、色調が近い骨材画像の判別については、必ずしも AI が正確とはならないことも把握できたことから、岩種判別では他の技術と併せて評価する必要があると考える。

## 4. 実際のコンクリート製造設備における AI 骨材粒径 / 岩種判別の全量管理の試み

### 4. 1 実プラントの概要および判別骨材の諸元

近年、ICT 技術の活用による i-Construction の推進において、コンクリートにおいても全数・全量管理の実現化に向けての研究開発が積極的に行われている。

そこで、前章までの基礎研究を踏まえ、実際のレディーミクストコンクリート製造設備（以下、実プラントと称す）に AI (Deep Learning) 骨材判別システムを設置して、コンクリート骨材の粒径および岩種の全量管理を試みた。

当該プラントは、粗骨材・細骨材共に一ヶ所の投入設備（同一ホップ）に投入されベルトフィーダで引き出された

後に急傾斜コンベヤでバッチャに搬送される形式であった。また、粗骨材および細骨材は、共にそれぞれ2種類の骨材をバッチャプラントで個別に計量しブレンドして用いる配合仕様であった。Table 9に、実プラントで使用された骨材の諸元およびブレンド比率を示す。特に、細骨材は粒径範囲が重複しており粗骨材でも粒径範囲がほぼ同様であるため、これまでは自動判別が技術的にも難しいと考えられていた。

今回、骨材撮影用のカメラボックスは、骨材投入ホップの直下のベルトフィーダ上に設置し、バッチャに搬送される骨材全量を連続的に撮影し判別する方式をとった (Fig. 8)。骨材画像の撮影にはエリアセンサカメラ (200万画素: カラータイプ, 分解能: 約 0.5mm/pixel) を使用し、防塵用のカメラボックスに入れて設置した。また、撮影画像への斜光の映り込みを防ぐために、カメラボックスの周囲は遮光部材で覆い、内部に LED 照明 (100W×2 台: 6000K) を取り付けた。なお、ベルトフィーダの搬送速度は

約 40m/min で、ホイールローダ 1 台 (3m<sup>3</sup>) 当たり投入ホップからの引き出し時間は約 90s、骨材の連続撮影および判別の時間間隔はデータ保存等を含め約 10s 毎であった。

## 4. 2 実プラントにおける骨材粒径判別

### 4. 2. 1 粒径判別の教師データと学習モデル

実プラントでの骨材は粒径の範囲がこれまでとは異なるので、いままでの AI 学習モデルは使用できない。そこで、新たに教師データを撮影して AI 学習モデルを再構築した。

AI による骨材粒径判別の教師データは、骨材ストックパイルよりサンプリングして、大型バットに敷き均し iPad で撮影した画像をモノクロに変換したものを用いた。AI 学習モデルの構築は、これまでと同様の方法で行った (Fig. 3)。なお、粗骨材 G<sub>31</sub> および G<sub>32</sub> については各 200 枚、細骨材については粗粒率の異なる砕砂 (S<sub>1</sub>) と陸砂 (S<sub>2</sub>) をそれぞれ 100 枚ずつ撮影して教師データとした。

### 4. 2. 2 粒径判別結果

Table 10 に、約 6 カ月間にわたって Deep Learning により骨材粒径の判別を実施した結果を示す。これより、ベルトフィーダを通過する骨材のほぼ全量について 99.5% 以上で Deep Learning により粒径の連続判別が行えることを確認できた。とりわけ細骨材については、約 68,000 枚の画像で誤判定は僅か 1 枚であった。なお、誤判定画像は、粒径の大きな粗骨材が混入していた画像であった。

すなわち、一般的な粗骨材と細骨材においては、ステレオカメラによる方法と同様、AI による方法は十分な精度で判別でき、極めて有効な方法であると言える。しかし、これら粒径判別技術では、粗粒率は異なるものの粒径の範囲が同じ細骨材の S<sub>1</sub> と S<sub>2</sub> を判別することは困難である。

そこで、前述した iPad で撮影したカラー画像 (モノクロに変換する前の画像) を教師データとして、AI 学習モデルを作成し、骨材岩種の全量判別を行うものとした。

## 4. 3 実プラントにおける骨材岩種判別

### 4. 3. 1 iPad で撮影したカラー画像による AI 学習モデルに基づく岩種判別

AI による骨材岩種判別の教師データとしては、粗骨材 (G<sub>31</sub>, G<sub>32</sub>) は骨材ストックパイルよりサンプリングして各 200 枚ずつ、細骨材も同様に砕砂 (S<sub>1</sub>) と陸砂 (S<sub>2</sub>) を新たに 200 枚ずつ iPad により撮影したカラー画像を用いて、それぞれ AI 学習モデルを作成した。

この AI 学習モデルにより岩種判別を行った結果、G<sub>31</sub> および S<sub>1</sub> については判定率が 99% 以上であったが、G<sub>32</sub> および S<sub>2</sub> については判定率が 70% 程度と極めて低い結果となった。この原因としては、iPad で撮影した教師データ画像とベルトフィーダ上に設置したカメラで撮影した検証画像の撮影環境の違いによるものと考えられた。すなわち、ホワイトバランスの補正は行っているものの、LED 照明下で撮影された検証画像は自然光に比べて光量が小さいの

Table 9 実プラントで使用された骨材の諸元

区分	粗骨材			細骨材		
	G <sub>31</sub> 20~13mm	G <sub>32</sub> 13~5mm	合成 (G <sub>31</sub> :G <sub>32</sub> =30:70) 20~5mm	S <sub>1</sub> ≦5mm	S <sub>2</sub> ≦5mm	合成 (S <sub>1</sub> :S <sub>2</sub> =75:25) 20~5mm
産地	福井県坂井市産			福井県坂井市産		
岩種	安山岩砕石	安山岩砕石	安山岩砕石	安山岩砕砂	陸砂	-
表乾密度 (g/cm <sup>3</sup> )	2.68	2.69	2.62	2.64	2.58	2.69
絶乾密度 (g/cm <sup>3</sup> )	2.64	2.65	2.57	2.59	2.52	2.65
吸水率 (%)	1.24	1.37	2.11	2.05	2.22	1.32
粗粒率	7.15±0.20	6.45±0.20	6.66±0.20	3.10±0.15	1.70±0.20	2.75±0.20

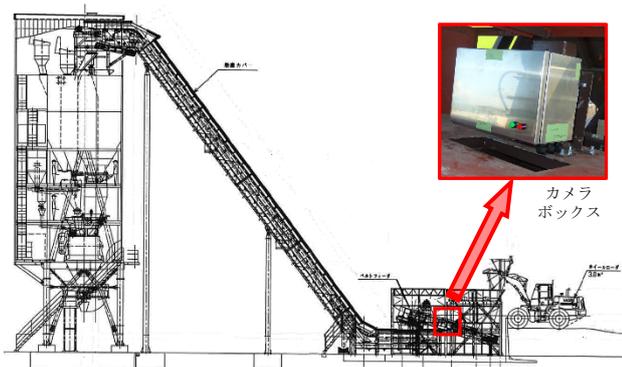


Fig. 8 実プラントへの骨材判別用カメラボックスの設置

Table 10 実プラントにおける骨材粒径判別結果

区分		Deep Learning			
		総数	Ok	誤判定	判定率
粗骨材	G <sub>31</sub> (20~13mm)	22,597	22,267	330	98.5
	G <sub>32</sub> (13~5mm)	43,594	43,202	392	99.1
細骨材	S (S <sub>1</sub> +S <sub>2</sub> )	68,386	68,385	1	100.0
合計		134,577	133,854	723	99.5

Table 11 骨材岩種判別における iPad による教師画像とベルトフィーダ上の検証画像の比較

区分	粗骨材		細骨材	
	G3 <sub>1</sub> (20~13mm)	G3 <sub>2</sub> (13~5mm)	S <sub>1</sub>	S <sub>2</sub>
教師画像 (iPadで撮影)	表乾			
	溼潤			
検証画像 (ベルトフィーダ上で撮影)				

Table 12 実プラントにおける骨材岩種判別結果

区分	総数	再学習によるAIモデル			iPad画像によるAIモデル			
		Ok	誤判定	判定率	Ok	誤判定	判定率	
粗骨材	G3 <sub>1</sub> (20~13mm)	22,597	22,528	69	99.7	22,586	11	100.0
	G3 <sub>2</sub> (13~5mm)	43,594	42,951	643	98.5	29,574	14,020	67.8
細骨材	砕砂 S <sub>1</sub>	41,285	41,072	213	99.5	40,975	310	99.2
	陸砂 S <sub>2</sub>	27,101	26,280	821	97.0	20,488	6,613	75.6
合計	134,577	132,831	1,746	98.7	113,623	20,954	84.4	

で、自然光で撮影した教師データの画像との色調差が生じて誤判定になるのではないかと考えられた (Table 11)。

そこで、検証画像と同じ条件のベルトフィーダ上で撮影した画像を教師データとして Deep Learning で再学習し、新たな AI 学習モデルを作成して AI 判定を試みた。

#### 4. 3. 2 再学習による AI 学習モデルに基づく判別

教師データは、検証画像と同じ条件でプラント試運転時に撮影した画像とし、4種類の各骨材についてそれぞれ200枚ずつ合計800枚をランダムにサンプリングした画像を用いて、AIモデルを再構築した。Table 12に、再構築したAIモデルによる実プラントにおける骨材岩種判別結果を、iPadで撮影した教師データに基づく結果と併せて示す。

これより、再学習後のAIモデルによれば、G3<sub>1</sub>を除けば全体的に判定率は向上できたことが分かる。すなわち、カラー画像を用いて Deep Learning により骨材岩種(種別)をAI判別する場合には、検証画像と同じ条件で撮影した画像を用いて学習モデルを作成することが重要であることが把握できた。

### 5. Deep Learning による骨材粒度分布推定の研究

#### 5. 1 実プラントでの骨材粒度分布推定の試行

これまでの研究の結果、高品質な画像を用いた Deep Learning による AI モデルによって、骨材の粒径および岩種の判別を高い精度で行えること、ならびに骨材の全量連

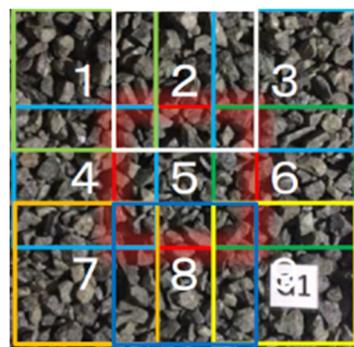


Fig. 9 ふるい分け試験時の教師データ画像の抽出し例

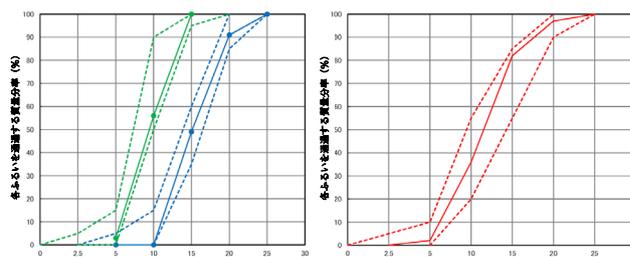


Fig. 10 粗骨材の教師データの一例 (ふるい分け試験結果、左：単体、右：合成)

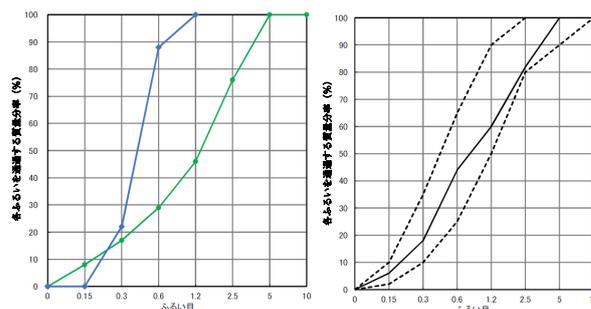


Fig. 11 細骨材の教師データの一例 (ふるい分け試験結果、左：単体、右：合成)

続管理が可能であることを確認した。一方、骨材の品質管理項目のうち粒度分布については、JIS法による試験が一般的であるが、試験における人的労力や時間的な負荷が大きいことなどから頻繁に試験を行うことが難しい場合が多く、日々の骨材の品質変動などに対しては十分に把握しきれないのが現状であった。一方、近年デジタルカメラを用いた画像処理による粒度管理技術<sup>6), 7), 8)</sup>などが開発されているが、サンプリング試料によるものや粒度分析までの処理時間が必要なものもあるようである。

そこで以下では、これまでの Deep Learning による AI 技術を踏まえて、その応用としてコンクリート骨材の粒度分布の推定の全量管理の可能性についての研究を行った。なお、開発した AI 粒度分布推定システムは、Fig. 8 に示した実プラントに設置し、骨材全量の連続推定を試みた。

#### 5. 2 教師データと AI 学習モデル, AI 粒度分布推定方法の概要

実プラントでの骨材の粒度分布の試験については、通常

週1回程度の頻度でJIS法による各骨材のふるい分け試験（JIS A 1102）が実施されている。本研究での教師データについては、ふるい分け試験に合わせてサンプリングした各骨材を、試験室内で大型バットに敷き均しそれぞれ5枚ずつ iPad で撮影する方法をとった。しかし、これだけでは教師データとしての画像の量が少ないので、撮影した写真1枚当たりから13.44×13.44cm（448×448pixel）で9ヶ所切り出し（Fig. 9）、5枚×9ヶ所からランダムに20枚の画像を抽出した。教師データは、この抽出画像と各骨材のふるい分け試験結果（各ふるいを通過する質量分率）とを関連付けて学習した。

Fig. 10 および Fig. 11 に粗骨材および細骨材の教師データにおける粒度曲線の一例を、Fig. 12 に教師データ（画像と粒度分布の試験結果）による Deep Learning の学習（画像識別）モデルの構築と AI 粒度分布推定の模式図を示す。

今回の教師データとしては、約5週間分の5回分のふるい分け試験に合わせて撮影・抽出した400枚（=骨材4種

×20枚×5回）の画像とふるい分け試験結果を用いた。

### 5.3 Deep Learning による骨材粒度分布の連続推定結果

Fig. 13 に、AI によって推定した各ふるいを通過質量分率から求めた日平均粗粒率と JIS 法による試験結果と併せて示す。なお、1日の平均的な画像枚数は、骨材毎にそれぞれ200~400枚程度であった。JIS 法と AI による推定値は概ね一致しており、AI による骨材粒度の推定は可能であると考えられる。また、JIS 法による試験ではおよそ1回/週であるが、AI による連続的な推定では原石山の地質や地層の変化等による粒度特性の急激な変動などを捉えることができるものと考えられる。

Fig. 14 に、粗粒率の JIS 法による試験結果と AI による日平均推定値との比較を示す。細骨材については推定誤差が5%を超える場合もありやや大きい傾向にあるが、粗骨材については高い精度で推定できており、全体としては十

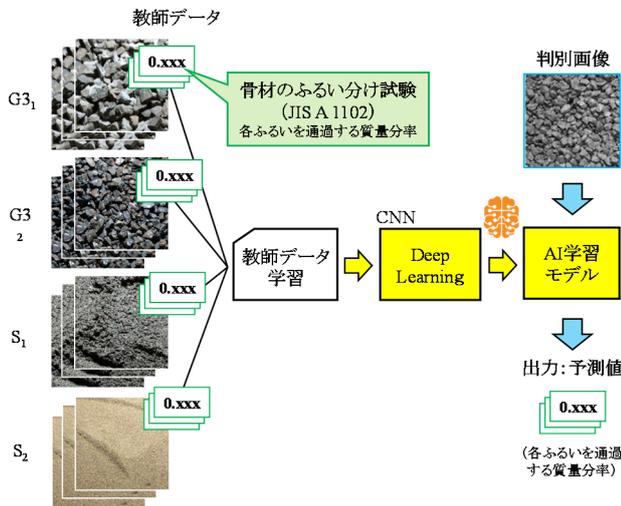


Fig. 12 教師データによる AI 学習モデルと AI 粒度分布推定の模式図

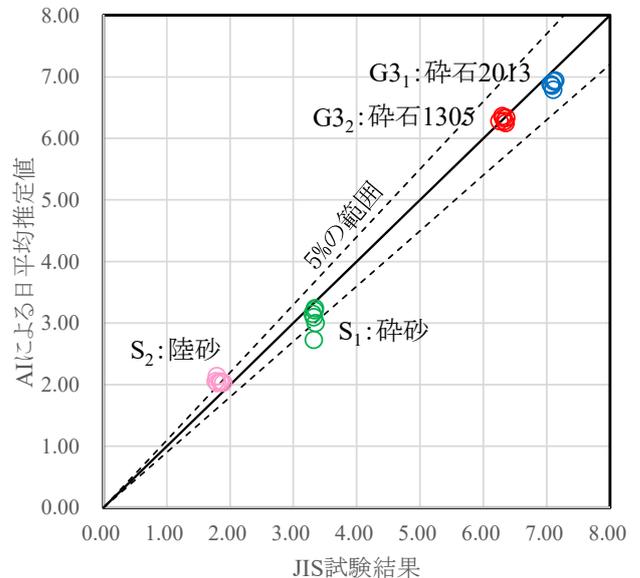


Fig. 14 JIS 試験結果と AI 日平均推定値との粗粒率の比較

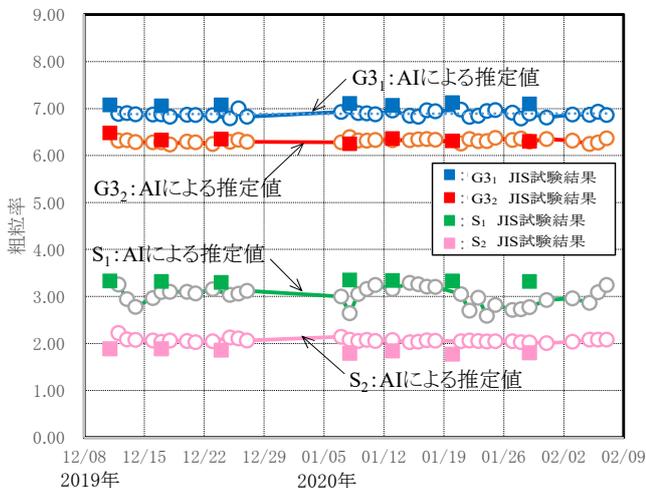


Fig. 13 AI による粗粒率の日平均推定値と JIS 法によるふるい分け試験結果

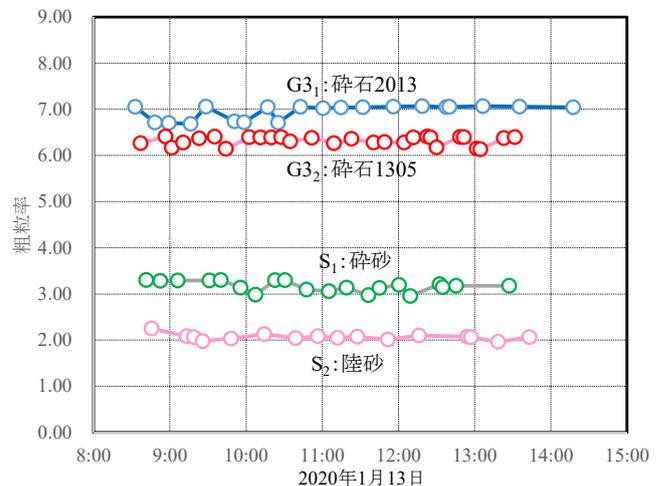


Fig. 15 AI による各投入バッチの平均粗粒率推定値の日内変動

Table 13 1バッチ内における粒径、岩種および粗粒率の判定結果の一例 (赤字：誤判定箇所)

骨材種別:G3 <sub>1</sub>				骨材種別:G3 <sub>1</sub>			
時刻	粒径判別	岩種判別	粗粒率	時刻	粒径判別	岩種判別	粗粒率
12:44:05	G3 <sub>1</sub>	G3 <sub>1</sub>	7.072	8:07:45	S	S <sub>1</sub>	3.305
12:44:16	G3 <sub>1</sub>	G3 <sub>1</sub>	7.052	8:08:09	G3 <sub>1</sub>	G3 <sub>1</sub>	7.070
12:44:27	G3 <sub>1</sub>	G3 <sub>1</sub>	7.058	8:08:20	G3 <sub>1</sub>	G3 <sub>1</sub>	7.063
12:44:37	G3 <sub>1</sub>	G3 <sub>1</sub>	7.064	8:08:30	G3 <sub>1</sub>	G3 <sub>1</sub>	7.076
12:44:48	G3 <sub>1</sub>	G3 <sub>1</sub>	7.048	8:08:41	G3 <sub>1</sub>	G3 <sub>1</sub>	7.07
12:44:58	G3 <sub>1</sub>	G3 <sub>1</sub>	7.071	8:08:52	G3 <sub>1</sub>	G3 <sub>1</sub>	7.07
12:45:08	G3 <sub>1</sub>	G3 <sub>1</sub>	7.059	8:09:02	G3 <sub>1</sub>	G3 <sub>1</sub>	7.076
12:45:18	G3 <sub>1</sub>	G3 <sub>1</sub>	7.076	8:09:11	G3 <sub>1</sub>	G3 <sub>1</sub>	7.014
12:45:28	G3 <sub>1</sub>	G3 <sub>1</sub>	7.063	8:09:21	G3 <sub>1</sub>	G3 <sub>1</sub>	6.985
12:45:38	S	S <sub>1</sub>	2.989	8:09:31	G3 <sub>1</sub>	G3 <sub>1</sub>	6.829

※:前のバッチはS<sub>2</sub> ※:前のバッチはS<sub>2</sub>

Table 14 実プラントにおける粗骨材の誤判定画像の一例

粗骨材	G3 <sub>1</sub> 20~13mm	G3 <sub>1</sub> 20~13mm
判別画像		
AI粒径判別	G3 <sub>1</sub>	S
AI岩種判別	G3 <sub>1</sub>	S <sub>1</sub>
AI粗粒率推定	7.063	2.989
時刻	12:45:28	12:45:38

分な精度で推定可能であるものと考えられる。

Fig. 15 に、各投入バッチにおける AI による平均粗粒率の推定値の日内変動の一例を示す。このように連続的に粗粒率の変動を監視することで、ブレンド比率の変更などコンクリート骨材としての合成粒度のきめ細かい品質管理を行える可能性があると考えられる。

なお、Table 13 に、実プラントにおける粒径および岩種の誤判定結果と粗粒率の AI 推定結果とを併せて示す。

これより、粒径および岩種の判定で誤判定と考えられた画像については、ホップからの引出し直後や最後で実際に粒径や粒度分布が小さい細粒分主体の骨材であった可能性があるものと考えられる。Table 14 に、ホップからの切出し終端における誤判定画像の一例を示す。粗骨材 G3<sub>1</sub> 上が細骨材で覆われており、粒径判別では S に、岩種判別では S<sub>1</sub> の AI 判定となっており、粗粒率については S<sub>1</sub> として評価されている。

すなわち、今回開発した AI モデルによれば、実際の現象を的確に連続的に捉えることができるものと考えられる。

## 6. まとめ

本研究では、Deep Learning を利用した骨材の粒径、岩種の判別および粒度分布の AI 推定の可能性について検証

を行ってきた。また、実プラントでの全量管理の可能性についても検討を行ってきた。

本研究で得られた知見をとりまとめて、以下に示す。

- (1) Deep Learningによるダムコンクリート用骨材の AI 学習モデルによれば、従来のステレオカメラと三次元画像処理による骨材粒径判別による方法に比べて判定率は1.2ポイント向上し、99.8%であった。
- (2) 粒径の範囲が同じ規格であれば、教師データと異なる骨材でも粒径の AI 判定率は99%以上と十分に良い精度で判別が可能である。
- (3) カラー画像を用いた AI 学習モデルにより、粒径範囲が同じ骨材でも岩種の AI 判別が可能である。ただし、教師データと検証データは同一撮影条件の画像を用いるのが望ましいと考えられる。
- (4) ふるい分け試験に用いた骨材画像と JIS 試験結果を学習させた AI モデルにより、十分な精度で骨材の粒度分布を推定できることが把握できた。
- (5) 特に、粗骨材は高い精度の粒度推定が可能で、細骨材についても誤差がやや見られるものの、材料の急激な変動などを捉えるには十分な精度であると考えられる。

以上より、良質な画像を用い適切な Deep Learning による AI 学習モデルを構築することで、瞬時に精度良くかつ連続的な骨材の全量管理が行えると考えられる。

今後は、実際の現場での運用・展開を図ると共に、画像の画角や粒径に応じた画像の分解能の変更など、骨材の全量管理について更に検討を行っていきたいと考える。

## 謝辞

本研究において、機材部北川博一氏の協力を得たと共に、AI 骨材判別システムの開発にあたりパシフィックシステム(株)の多大なるご尽力を頂きました。また、実プラント試験では、作業所長をはじめ関係各位にご協力を頂きました。ここに、深く感謝の意を表する次第である。

## 参考文献

- 1) 佐藤英明, 北川博一, 戸田修実, 金田修一: コンクリート骨材の粒径判別システムの開発, 土木学会第 69 回年次学術講演会, 2014.
- 2) 佐藤英明, 北川博一, 戸田修実: ステレオカメラを利用した骨材粒径判別システムの開発, 熊谷組技術研究報告, 第 75 号, pp. 51-58, 2016.
- 3) 北川博一, 佐藤英明: Deep Learning によるコンクリート骨材の粒径判別技術に関する基礎的研究, 令和元年度土木学会全国大会第 74 回年次学術講演会, 2019.
- 4) 佐藤英明, 北川博一: Deep Learning によるコンクリート骨材の岩種判別技術に関する基礎的研究, 令和元年度土木学会全国大会第 74 回年次学術講演会, 2019.
- 5) 佐藤英明, 北川博一: Deep Learning によるコンクリート骨材の粒度分布推定に関する基礎的研究, 令和 2 年度土木学会全国大会第 75 回年次学術講演会, 2020.
- 6) 藤崎勝利, 黒沼 出, 川野健一, 武井 昭: デジタルカメラ画像を

用いたCSG材の粒度変動監視システム, ダム工学, Vol. 23, No. 1,  
pp. 19-26, 2013.  
7) 田中麻穂, 安井利彰, 中島具威: 画像処理によるCSG材の粒度分

布推定技術の開発, 土木学会第70回年次学術講演会, VI-386, 2015.  
8) 石井喬之, 畠山峻一, 片山三郎, 新井博之: ICTを活用したCSG材  
品質管理手法の検討, 30(1), pp. 6-17, 2020.

---

## **A Study on AI Discrimination Technology for Concrete Aggregates using Deep Learning**

Hideaki SATOH

### **Abstract**

In the quality control of concrete, misplacement and improper mixing of aggregates are important issues that must be overcome. In this study, in order to prevent misplacement of aggregates, the author investigated a new technology that applies Deep Learning to identify grain size and rock type of aggregates. The author also studied the application of AI technology for estimating the grain distribution of aggregates. As a result, it became clear that the image recognition AI technology based on sufficient high-quality data can not only instantly determine the grain size and rock type of all aggregates, but also estimate the grain distribution with sufficient accuracy.

**Key words:** Aggregates, Prevention of misplacement, AI (Artificial Intelligence), Deep Learning, Grain distribution

---